

## ГІСТОГРАМНІ ОЦІНКИ ФОРМИ ФУНКЦІЇ КОНЦЕНТРАЦІЇ ДВОКОМПОНЕНТНОЇ СУМІШІ

УДК 519.21

Д. І. ПОХИЛЬКО

**АНОТАЦІЯ.** В роботі розглянуто питання про побудову проєкційних оцінок форми функції концентрації з розкладом за базисом індикаторних функцій (гістограмним базисом) для даних, що являють собою вибірку з суміші двох компонент з невідомими розподілами, концентрація яких змінюється протягом спостережень. Доведено консистентність оцінок і оцінено швидкість збіжності м.н.

### 1. ВСТУП

Суміші різних ймовірнісних розподілів часто використовуються у статистиці як математичні моделі розподілу реальних даних. Класична модель суміші має вигляд

$$P\{\xi \in A\} = w^1 H_1(A) + w^2 H_2(A) + \dots + w^M H_M(A)$$

де  $M$  – кількість компонент суміші,  $H_m$  – деякі ймовірнісні розподіли,  $w^m$  – концентрація  $m$ -тої компоненти у суміші. Як правило, їх використовують, коли об'єкти, що спостерігаються, можуть належати одному з  $M$  різних класів (популяцій, компонент), розподіли їх спостережуваних характеристик ( $\xi$ ) дорівнюють  $H_m$  для  $m$ -тої компоненти, а ймовірність спостерігати об'єкт з  $m$ -тої компоненти дорівнює  $w^m$ . Якщо невідомо, до якої популяції належать спостережувані об'єкти, ми отримуємо у точності класичну модель суміші, (див. [5] та список літератури в цій роботі).

Питання про побудову оцінок розподілу при відомих концентраціях розглядається в [1, 4]. Задачі оцінки щільності розподілу і класифікації по сумішах зі змінними концентраціями розглядаються в [10, 11].

Ми розглянемо задачу оцінювання функції концентрації у випадку, коли концентрації компонент змінюються від спостереження до спостереження, і суміш складена з двох компонент, розподіли яких невідомі. Тобто, спостереження  $\xi_j$  є незалежними в сукупності і

$$P\{\xi_j \in A\} = w(t_j)H_1(A) + (1 - w(t_j))H_2(A),$$

де  $w(t_j)$  – концентрація 1-ої компоненти суміші в момент часу  $t_j$  коли проводилось  $j$ -те спостереження. Цю задачу можна було б розв'язувати з використанням методів непараметричної регресії (див. в [8]). Дійсно, якщо  $\eta_1, \eta_2$  – в.в. з скінченним математичним сподіванням, що описують характеристики компонент, то  $\xi_j$  допускає зображення  $\xi_j = w(t_j)(E\eta_1 - E\eta_2) + E\eta_2 + \varepsilon_j$ , де  $\varepsilon_j$  – “шум” (незалежні центровані в.в.). Але при такому підході ми втрачаємо важливу інформацію про  $w(t_j)$ , яка міститься в  $\varepsilon_j$ . Наприклад, якщо  $E\eta_1 = E\eta_2$ , то на основі регресійного підходу не можна оцінити  $w(t_j)$ . Оцінка, розглянута в даній роботі, є консистентною і при  $E\eta_1 = E\eta_2$ , для такого випадку побудовано приклад оцінки в п. 3.

Проектування на гістограмний базис є частковим випадком застосування техніки проєкції на вейвлет-базис (див. [7, 6]). Використання вейвлетів в статистиці розглянуто в [9, 12]. В [9] розглянуто питання про застосування вейвлетів до задач непараметричної регресії.

Оцінки, розглянуті в роботі, аналогічні проєкційним оцінкам, розглянутим в [2, 3], побудованим з розкладом по тригонометричному базису. В [3] побудовано оцінки для функцій розподілу компонент суміші, які можна отримати, маючи оцінку функції концентрації.

## 2. ПОСТАНОВКА ЗАДАЧІ І ПОВБУДОВА ОЦІНКИ

Нехай  $\{\xi_j^N, j = 1, \dots, N\}_{N \geq 1}$  — послідовність серій випадкових векторів в  $\mathbb{R}^d$ , таких, що для всіх  $N$  вектори  $\{\xi_j^N, j = 1, \dots, N\}$  — незалежні в сукупності,

$$P\{\xi_j^N < x\} = F(t_j, x) = w(t_j)G(x) + (1 - w(t_j))H(x), \quad (1)$$

де  $G, H$  — функції розподілу (ф.р.) на  $\mathbb{R}^d$ ,  $w: [0, 1] \rightarrow [0, 1]$  — концентрація компоненти  $G$  в час  $t_j = j/N$ . Позначимо  $\text{Lip}_\beta$  — клас Липшица порядку  $\beta$ , тобто  $\text{Lip}_\beta[0, 1] = \{f: [0, 1] \rightarrow \mathbb{R} \mid \text{існує } L': \sup_{t,s \in [0,1]} |f(t) - f(s)| \leq L'|t - s|^\beta\}$ ,

$$\Sigma(\beta, L') = \left\{ f: [0, 1] \rightarrow \mathbb{R} \mid \sup_{t,s \in [0,1]} |f(t) - f(s)| \leq L'|t - s|^\beta \right\}.$$

В цій роботі розглянуто задачу оцінювання форми  $w$  за спостереженнями  $\xi_j^N$  в припущенні  $w \in \text{Lip}_\beta[0, 1]$ , де  $\beta \in [0, 1]$  — фіксоване (відоме),  $G, H$  — невідомі.

Функцію  $F(t, x)$  можна подати у вигляді

$$F(t, x) = G_1(x) + u(t)G_2(x), \quad (2)$$

де

$$G_1(x) = H(x) + abG_2(x), \quad G_2(x) = \frac{G(x) - H(x)}{a},$$

$$u(t) = a(w(t) - b), \quad b = \int_0^1 w(t) dt, \quad a = \left( \int_0^1 (w(t) - b)^2 dt \right)^{-1/2}.$$

Зрозуміло, що

$$\int_0^1 (u(t))^2 dt = 1, \quad \int_0^1 u(t) dt = 0. \quad (3)$$

Якщо  $w(t)$  — функція концентрації, то  $u(t)$  — її форма. Як показано в [2], розклад (2) при виконанні умов нормування (3) стає однозначним з точністю до знаку  $u(t)$ . Якщо не вимагати виконання (3), то розклад стає неоднозначним. Тому надалі будемо оцінювати  $u(t)$ , визначене (2)–(3). Таким чином, ми оцінюємо форму функції концентрації, тобто функцію концентрації з точністю до зсуву та масштабу.

Ми будемо шукати функцію  $u_N^*(t)$ , яка добре наближує  $u$  на рівномірній сітці часу, тому на роль критерія якості підгонки оберемо

$$\sqrt{\frac{1}{N} \sum_{k=1}^N \left( u\left(\frac{k}{N}\right) - u_N^*\left(\frac{k}{N}\right) \right)^2}.$$

При побудові оцінки  $u_N^*(t)$  використаємо підхід, запропонований в [2]. Для цього будемо проєктувати  $F(t, x)$  на клас функцій

$$F_v(t, x) = G_1(x) + v(t)G_2(x),$$

де  $v \in V$ ,  $V$  — скінченновимірний клас функцій в  $L_2([0, 1], m)$ , ( $m$  тут і надалі — міра Лебега), причому  $v$  задовольняє умовам нормування (3). Нехай  $\pi(\cdot)$  — деяка

ймовірнісна міра на  $\mathbb{R}^d$ ,  $\Delta$  — носій міри  $\pi$ . Шукатимемо  $v$ , яке задовольняє (3) і мінімізує величину

$$\sqrt{\frac{1}{N} \int_{\Delta} \sum_{k=1}^N \left( F\left(\frac{k}{N}, x\right) - F_v\left(\frac{k}{N}, x\right) \right)^2 \pi(dx)}. \quad (4)$$

Позначимо  $\lambda_N$  — ймовірнісну рахуючу міру, що зосереджена в точках  $t_j^N = j/N$ ,  $j = 1, \dots, N$ , тобто  $\lambda_N(\{t_j^N\}) = 1/N$ . Тут і надалі під  $\|\cdot\|_N$ ,  $\langle \cdot, \cdot \rangle_N$  будемо розуміти, відповідно, норму і скалярний добуток в просторі  $L_2([0, 1], \lambda_N)$ , під  $\|\cdot\|_2$  — норму в  $L_2([0, 1], m)$ , тоді в цих позначеннях

$$\sqrt{\frac{1}{N} \sum_{k=1}^N (u(t_k^N) - u_N^*(t_k^N))^2} = \|u - u_N^*\|_N.$$

Позначимо  $\mathbb{H} = L_2([0, 1] \times \Delta, \lambda_N \times \pi)$ , тоді задача мінімізації (4), тобто мінімізації  $\|F_v - F\|_{\mathbb{H}}$  на  $V$  еквівалентна максимізації

$$\begin{aligned} D(v) &= \int_{\Delta} \left( \int_{[0,1]} v(t) F(t, x) \lambda_N(dt) \right)^2 \pi(dx) \\ &= \frac{1}{N^2} \int_{\Delta} \int_{\Delta} \left( \sum_{k=1}^N v\left(\frac{k}{N}\right) F\left(\frac{k}{N}, x\right) \right)^2 \pi(dx). \end{aligned} \quad (5)$$

Оскільки функція розподілу  $F(t, x)$  нам невідома, то шукатимемо оцінку для  $v$ , підставляючи в (5) оцінку для  $F$ . Зрозуміло, що побудова оцінки буде залежати лише від вибору  $V$  і, наприклад, якщо  $\{f_i, i = 1, \dots, l\}$  — деякий ортонормований базис (ОНБ) з.л.о. ( $V$ ) в  $L_2([0, 1], \lambda_N)$ , то оцінку  $u_N^*$  можна побудувати так

$$u_N^* = \sum_{i=1}^l c_N^i f_i, \quad (6)$$

де  $c_N = (c_N^i, i = 1, \dots, l)$  — власний вектор матриці  $(d_{ij}^N)_{i,j=1}^l$ , що відповідає найбільшому власному числу, де

$$d_{ij}^N = \frac{1}{N^2} \sum_{k=1}^N f_i(t_k^N) f_j(t_k^N) \int_{\Delta} \mathbb{I}\{\xi_i^N < x, \xi_k^N < x\} \pi(dx), \quad (7)$$

(див. [2, 3]).

Введемо наступні позначення:

$$g_k^i(t) := \sqrt{l+1} \mathbb{I}\left\{t \in \left(\frac{k}{l+1}, \frac{k+1}{l+1}\right]\right\}, \quad V_i = \text{з.л.о.}\{g_k^i, k = 0, \dots, l\},$$

замикання береться в просторі  $L_2([0, 1], \lambda_N)$ ;  $U_l = \text{з.л.о.}\{g_k^i, k = 0, \dots, l\}$ , замикання береться в просторі  $L_2([0, 1], m)$ ,  $\{g_k^i, k = 0, \dots, l\}$  — ОНБ в  $U_l$ . Нехай

$$\{f_j^{NI}(t), j = 0, \dots, l\}$$

— ОНБ в  $V_l$  відносно скалярного добутку  $\langle \cdot, \cdot \rangle_N$ , при цьому покладемо  $f_0^{NI} \equiv 1$ ,  $W_l = \text{з.л.о.}\{f_k^{NI}, k = 1, \dots, l\}$ , замикання береться в просторі  $L_2([0, 1], \lambda_N)$ .

**Теорема 2.1.** Нехай виконано (2) з обмеженнями (3),

$$\int_{\Delta} (G_2(x))^2 \pi(dx) > 0, \quad u \in \Sigma(\beta, L'), \quad \beta \in (0, 1],$$

оцінка  $u_N^*$  визначена (6), (7), де в якості  $V$  виступає  $W_l$ . Якщо  $l = N^\alpha$ ,  $\alpha \in (0, \frac{1}{2})$ ,

- (1)  $\min_{\sigma=\pm 1} \|u - \sigma u_N^*\|_N = O(r_N(\alpha, \beta))$  м.н.,  $N \rightarrow \infty$ , де  
 $r_N(\alpha, \beta) = (\ln N)^{1/4} N^{\alpha/2-1/4} + N^{-\alpha\beta}$ ;
- (2)  $\min_{\sigma=\pm 1} \|u - \sigma u_N^*\|_2 = O(r_N(\alpha, \beta))$  м.н.,  $N \rightarrow \infty$ .

Нам будуть потрібні наступні леми.

**Лема 2.1.** Нехай  $z = (z^1, \dots, z^l) \in \mathbb{R}^l$ ,  $\|z\| \in [\frac{1}{2}, 2]$ ,  $u_z = \sum_{i=1}^l z^i f_i^{Nl}$ ,  
 $F(t, x) = G_1(x) + u_z(t)G_2(x) + \Delta_N(t, x)$ ,

де  $\Delta_N(t, x)$  — довільна функція. Для довільного  $\zeta \in \mathbb{R}^l$ , такого що  $\|\zeta\| = 1$  (норма в  $\mathbb{R}^l$ ) покладемо

$$\Delta_\zeta(x) = \int_{[0,1]} u_\zeta(t) \Delta_N(t, x) \lambda_N(dt), \quad C = \int_{\Delta} (G_2(x))^2 \pi(dx),$$

$$D(\zeta) := D(u_\zeta) = \int_{\Delta} \left( \int_{[0,1]} u_\zeta(t) (G_1(x) + u_z(t)G_2(x) + \Delta_N(t, x)) \lambda_N(dt) \right)^2 \pi(dx),$$

$$R(\zeta) = \int_{\Delta} G_2(x) \Delta_\zeta(x) \pi(dx), \quad Q(\zeta) = \int_{\Delta} (\Delta_\zeta(x))^2 \pi(dx),$$

$$\Delta_\zeta = 4|R(\zeta)| + Q(\zeta), \quad \delta = \delta_N = \sup_{\|\zeta\|=1} \Delta_\zeta, \quad v = \operatorname{argmax}_{\|\zeta\|=1} D(\zeta),$$

тоді

$$\min_{\sigma=\pm 1} \|u_z - \sigma u_v\|_N \leq \|z\| - 1 + 4\sqrt{\delta/C}.$$

Зауважимо, що  $\|z\| = \|u_z\|_N$ . Дана лема є модифікацією леми 1 в [3].

*Доведення.* Можна показати, що

$$D(\zeta) = C \langle u_\zeta, u_z \rangle_N^2 + 2 \langle u_\zeta, u_z \rangle_N R(\zeta) + Q(\zeta).$$

Покладемо  $y = z / \|z\|$ , тоді  $\|y\| = 1$ ,  $z = y \|z\|$ . Отримаємо подання

$$D(\zeta) = C \|z\|^2 \langle u_\zeta, u_y \rangle_N^2 + 2R(\zeta) \|z\| \langle u_\zeta, u_y \rangle_N + Q(\zeta).$$

Аналогічно тому, як це зроблено в [3], можна отримати

$$\min_{\sigma=\pm 1} \|u_y - \sigma u_v\|_N \leq 4\sqrt{\frac{\delta}{C}}.$$

Тому з нерівності трикутника отримаємо

$$\min_{\sigma=\pm 1} \|u_z - \sigma u_v\|_N \leq \|u_z - u_y\|_N + \min_{\sigma=\pm 1} \|u_y - \sigma u_v\|_N \leq \|z\| - 1 + 4\sqrt{\frac{\delta}{C}}. \quad \square$$

Наступна лема доводиться в [2, Л.3.6.3].

**Лема 2.2.** Якщо виконуються умови теореми 2.1,

$$u(t) = \sum_{i=1}^l c_i^{Nl} f_i^{Nl}(t) + u^0(t),$$

де  $\|c\| = 1$  (норма вектора в  $\mathbb{R}^l$ ),  $\langle u^0, f_i^{Nl} \rangle_N = 0$ ,  $i = 1, \dots, l$ ,

$$\Delta_N(t, x) = \mathbb{I}\{\xi_{k(t)}^N < x\} - G_1(x) - \sum_{i=1}^l c^i f_i^{Nl}(t) G_2(x), \quad (8)$$

$k(t) = \min\{y \in \mathbb{Z} \mid y/N \geq t\}$ , то в позначеннях леми 2.1

$$\delta_N = O((\ln N)^{1/2}) N^{\alpha-0.5} \quad \text{м.н.}$$

Зауважимо, що при такому, як в (8), виборі  $\Delta_N(t, x)$  функція  $u_v$  з леми 2.1 переходить в оцінку  $u_N^*$ , визначену в (6).

Застосувавши теорему про середнє для неперервних функцій, можна отримати наступне твердження:

**Лема 2.3.** Нехай  $u: [0, 1] \rightarrow \mathbb{R}$ ,  $u \in \Sigma(\beta, L')$ . Тоді  $\sup_{t \in (0, 1)} |u(t) - v(t)| \leq L'l^{-\beta}$ , де  $v(t) = \text{Pr}_{U_l} u(t)$ , проєкція будується в просторі  $L_2((0, 1], m)$ .

**Лема 2.4.** Нехай  $N \geq 4$ ,  $l = N^\alpha$ ,  $\alpha \in (0, \frac{1}{2})$ ;  $u, v: [0, 1] \rightarrow \mathbb{R}$ ;  $u \in \Sigma(\beta, L')$ ,

$$v(t) = \sum_{k=0}^l c_k \mathbb{I} \left\{ t \in \left( \frac{k}{l+1}, \frac{k+1}{l+1} \right) \right\}.$$

Тоді існують  $K_i = K_i(L') \in \mathbb{R}$ ,  $i = 1, 2, 3$ :

$$\|u - v\|_2 \leq K_1 N^{-\beta} + K_2 \|u - v\|_N + K_3 N^{-\beta/2} \|u - v\|_N^{1/2}.$$

*Доведення.* Маємо

$$\begin{aligned} \|u - v\|_2^2 &= \int_0^1 (u(t) - v(t))^2 dt = \sum_{k=0}^l \int_{\frac{k}{l+1}}^{\frac{k+1}{l+1}} (u(t) - v(t))^2 dt \\ &\leq \sum_{k=0}^l \sum_{s \in \mathbb{Z}: (\frac{s}{N}, \frac{s+1}{N}] \subset (\frac{k}{l+1}, \frac{k+1}{l+1})} \int_{\frac{s}{N}}^{\frac{s+1}{N}} (u(t) - v(t))^2 dt \\ &\quad + \sum_{k=0}^l \int_{\frac{s_k}{N}}^{\frac{s_{k+1}}{N}} (u(t) - v(t))^2 dt \\ &= S_1 + S_2, \end{aligned}$$

де  $s_k$  обираються з умови  $s_k \in \mathbb{Z}$ ,

$$\frac{Nk-1}{l+1} < s_k \leq \frac{kN}{l+1}.$$

При такому підсумовуванні в першій сумі ( $S_1$ ) для всіх  $t \in (s/N, (s+1)/N]$

$$v(t) = v\left(\frac{s}{N}\right),$$

а всі точки, де  $v(t)$  може змінити значення всередині проміжку інтегрування, віднесені в другу суму ( $S_2$ ). Вимагатимемо  $N \geq 4$ , щоб всередині інтервалу довжиною  $1/N$  функція  $v(t)$  не змінювала своє значення більше одного разу.

Оцінимо  $S_1$ . Враховуючи, що для доданків з  $S_1$  для всіх  $t \in (s/N, (s+1)/N]$ ,

$$v(t) = v\left(\frac{s+1}{N}\right),$$

можемо мажорувати їх величиною

$$\frac{1}{N} \left( u\left(\frac{s+1}{N}\right) - v\left(\frac{s+1}{N}\right) \right)^2 + \frac{2L'N^{-\beta}}{N} \left| u\left(\frac{s+1}{N}\right) - v\left(\frac{s+1}{N}\right) \right| + \frac{L'^2 N^{-2\beta}}{N}.$$

Для  $S_2$

$$\begin{aligned} &\int_{\frac{s_k}{N}}^{\frac{s_{k+1}}{N}} (u(t) - v(t))^2 dt \\ &\leq \int_{\frac{s_k}{N}}^{\frac{s_{k+1}}{N}} \left( u(t) - v\left(\frac{s_k}{N}\right) \right)^2 dt + \int_{\frac{s_k}{N}}^{\frac{s_{k+1}}{N}} \left( u(t) - v\left(\frac{s_k+1}{N}\right) \right)^2 dt = I_1 + I_2. \end{aligned}$$

Величину  $I_2$  вже оцінено вище, оцінимо  $I_1$ . Використавши теорему про середнє для  $u$ , можна показати, що

$$I_1 \leq \frac{L^2 N^{-2\beta}}{N} + \frac{2L' N^{-\beta}}{N} \int_{\frac{k-1}{N}}^{\frac{k}{N}} |u(t) - v\left(\frac{k}{N}\right)| dt + \int_{\frac{k-1}{N}}^{\frac{k}{N}} (u(t) - v\left(\frac{k}{N}\right))^2 dt.$$

Отже, існують такі  $C_1, C_2, C_3 \in \mathbb{R}$ , що

$$\begin{aligned} S_1 + S_2 &\leq C_1 N^{-2\beta} + \frac{C_2}{N} \sum_{k=1}^N \left( u\left(\frac{k}{N}\right) - v\left(\frac{k}{N}\right) \right)^2 + \frac{C_3 N^{-\beta}}{N} \sum_{k=1}^N \left| u\left(\frac{k}{N}\right) - v\left(\frac{k}{N}\right) \right| \\ &\leq C_1 N^{-2\beta} + C_2 \|u - v\|_N^2 + C_3 N^{-\beta} \|u - v\|_N, \end{aligned}$$

що і доводить лему.  $\square$

*Доведення теореми 2.1.* Скористаємося нерівністю трикутника:

$$\min_{\sigma=\pm 1} \|u - \sigma u_N^*\|_N \leq \|u - \tilde{u}_t\|_N + \|\tilde{u}_t - \hat{u}_t\|_N + \min_{\sigma=\pm 1} \|\hat{u}_t - \sigma u_N^*\|_N,$$

де  $\tilde{u}_t = \text{Pr}_{V_t} u$ ,  $\hat{u}_t = \text{Pr}_{W_t} u$ , проекція будується в просторі  $L_2((0,1], \lambda_N)$ . Оцінимо перший доданок. Використавши позначення леми 2.3 і те, що  $v_t \in V_t$ , де  $v_t = \text{Pr}_{U_t} \hat{u}_t$ , можемо записати:

$$\|u - \tilde{u}_t\|_N = \min_{y \in V_t} \|u - y\|_N \leq \|u - v_t\|_N \leq \sup_{t \in (0,1]} |u(t) - v_t(t)| \leq L' N^{-\alpha\beta}.$$

Оцінимо другий доданок. Оскільки  $W_t \subset V_t$  і  $\int_{[0,1]} u(t) dt = 0$ , то

$$\begin{aligned} \|\tilde{u}_t - \hat{u}_t\|_N &= \|\text{Pr}_{V_t \ominus W_t} u\|_N = |\langle u, f_0^{N,t} \rangle_N| = \left| \int_{[0,1]} u(t) \lambda_N(dt) \right| \\ &= \left| \int_{[0,1]} u(t) dt - \int_{[0,1]} u(t) \lambda_N(dt) \right| \leq \sum_{k=1}^N \int_{\frac{k-1}{N}}^{\frac{k}{N}} \left| u(t) - u\left(\frac{k}{N}\right) \right| dt \leq L' N^{-\beta}. \end{aligned}$$

Оцінимо величину  $|1 - \|\hat{u}_t\|_N|$ :

$$\begin{aligned} |1 - \|\hat{u}_t\|_N| &\leq |1 - \|u\|_N| + \|u\|_N - \|\hat{u}_t\|_N + \|\hat{u}_t\|_N - \|\tilde{u}_t\|_N \\ &\leq |1 - \|u\|_N| + \|u - \tilde{u}_t\|_N + \|\tilde{u}_t - \hat{u}_t\|_N \leq |1 - \|u\|_N| + L' N^{-\alpha\beta} + L' N^{-\beta}, \\ |1 - \|u\|_N| &= \frac{|1 - \|u\|_N^2|}{1 + \|u\|_N} \leq \frac{\|u\|_2^2 - \|u\|_N^2}{1 + \|u\|_N} = \left| \sum_{k=1}^N \int_{\frac{k-1}{N}}^{\frac{k}{N}} \left( u^2(t) - u^2\left(\frac{k}{N}\right) \right) dt \right| \\ &\leq 2 \sup_{t \in (0,1]} |u(t)| \frac{1}{N} \sum_{k=1}^N \sup_{t \in (\frac{k-1}{N}, \frac{k}{N})} \left| u(t) - u\left(\frac{k}{N}\right) \right| \leq 2L^2 N^{-\beta}. \end{aligned}$$

Тут було використано те, що для нормованих просторів  $\| \|a\| - \|b\| \| \leq \|a - b\|$  і те, що з  $w \in \Sigma(\beta, L')$  і


$$\int_{[0,1]} u(t) dt = 0$$

випливає  $\sup_{t \in [0,1]} |u(t)| \leq L'$ . Таким чином

$$|1 - \|\hat{u}_t\|_N| \leq C_1' N^{-\beta} + L' N^{-\alpha\beta},$$

тому при достатньо великих  $N$  виконуються умови леми 2.1, і отже:

$$\begin{aligned} \min_{\sigma=\pm 1} \|\hat{u}_t - \sigma u_N^*\|_N &\leq C_1' N^{-\beta} + L' N^{-\alpha\beta} + 4\sqrt{\frac{\delta_N}{C}}, \\ \min_{\sigma=\pm 1} \|u - \sigma u_N^*\|_N &\leq C_1 N^{-\beta} + C_2 N^{-\alpha\beta} + C_3 \sqrt{\delta_N}, \end{aligned}$$

Рис. 1. Усереднена відстань  $\min_{\sigma=\pm 1} \|u - \sigma u_N^*\|_2$  для прикладу А

де  $\delta_N$  оцінена в лемі 2.2, що і доводить перше твердження теореми, друге випливає з першого і лемі 2.4.  $\square$


Швидкість збіжності, отримана в цій теоремі, співпадає з швидкістю збіжності для оцінок, побудованих з розкладом по тригонометричному базису (див. [3]).

### 3. ПОВЕДІНКА ОЦІНКИ НА МОДЕЛЬОВАНИХ ДАНИХ

Розглянемо два приклади. Нехай для обох  $w(t) = 4(t - \frac{1}{2})^2 \mathbb{I}\{t \in [0, 1]\}$ , для прикладу А)  $\pi(A) = m(A \cap [0, 1])$  для всіх  $A \in \mathcal{B}(\mathbb{R})$ ; для прикладу В)  $\pi(A) = \frac{1}{2}m(A \cap [0, 2])$  для всіх  $A \in \mathcal{B}(\mathbb{R})$ , функції розподілу такі:

$$\begin{aligned}
 \text{А)} \quad G(x) &= \begin{cases} 0, & x < 0, \\ x, & 0 \leq x \leq 1, \\ 1, & 1 \leq x, \end{cases} & H(x) &= \begin{cases} 0, & x < 0.25, \\ 2(x - 0.25), & 0.25 \leq x \leq 0.75, \\ 1, & 0.75 \leq x, \end{cases} \\
 \text{В)} \quad G(x) &= \begin{cases} 0, & x < 0, \\ x, & 0 \leq x \leq 1, \\ 1, & 1 \leq x, \end{cases} & H(x) &= \begin{cases} 0, & x < 1, \\ x - 1, & 1 \leq x \leq 2, \\ 1, & 2 \leq x. \end{cases}
 \end{aligned}$$

З використанням пакету Mathematica 5 була змодельована суміш компонент з даними розподілами з функцією концентрації  $w(t)$ . По суміші була побудована оцінка  $u_N^*(t)$  і обчислено  $\min_{\sigma=\pm 1} \|u - \sigma u_N^*\|_2$ . Усереднені результати 30–50 експериментів для кожного набору параметрів наведені в таблиці. В першій колонці (під титулом  $N$ ) йде довжина вибірки, по яким будувались оцінки, титули ( $l = 5, 10, \dots$ ) відповідають кількості індикаторних функцій в базисі, по якому будується  $V_l$  (тобто  $V_l = \text{з.л.о.}\{g_k, k = 1, \dots, l\}$ ,  $g_k(x) = \sqrt{l} \mathbb{I}\{x \in (\frac{k-1}{l}, \frac{k}{l})\}$ ), буквами А, В помічено колонки з даними для відповідних прикладів. В першій стрічці під титулами 5, 10, ...

Рис. 2. Усереднена відстань  $\min_{\sigma=\pm 1} \|u - \sigma u_N^*\|_2$  для прикладу B

йдуть відстані  $\|u - \text{Pr}_{V_1} u\|_2$ .

N	5		10		15		20	
	A	B	A	B	A	B	A	B
	0.440		0.223		0.149		0.112	
900	0.497	0.463	0.397	0.259	0.424	0.233	0.459	0.232
1200	0.477	0.459	0.345	0.256	0.367	0.212	0.371	0.206
1500	0.472	0.458	0.302	0.248	0.317	0.200	0.315	0.200
1800	0.464	0.456	0.302	0.241	0.301	0.194	0.294	0.174
2100	0.466	0.454	0.282	0.240	0.255	0.184	0.284	0.175

На графіках показані результати для обох прикладів для трьох значень  $l$ : 10 — ромбами, 15 — зірочками, 20 — квадратами. Відстані відкладені по осі Y, величини вибірки — по N.

#### 4. Висновки

Таким чином, ми розглянули питання про побудову проєкційних оцінок форми функції концентрації з розкладом за гістограмним базисом для даних, що являють собою вибірку з суміші двох компонент з невідомими розподілами, концентрація яких змінюється протягом спостережень. Доведено консистентність оцінок і оцінено швидкість збіжності м.н. Показано, що швидкість збіжності для оцінок, побудованих за гістограмним базисом має той самий порядок, що і для оцінок, побудованих за тригонометричним базисом.

Результати імітаційного моделювання показали, що у випадку розподілів, які легко розрізняються (приклад B), величина похибки досить помірна вже при порівняно невеликих обсягах вибірки, зменшення похибки відбувається головним чином при збільшенні кількості базисних функцій. У випадку, коли розподіли розрізняються гірше (приклад A), похибка "стартує" з досить великих значень (майже 0.5 норми функції, що оцінюється), проте із зростанням обсягу вибірки помітно зменшується: ефект зменшення похибки при збільшенні кількості елементів гістограмного базису проявляється значно слабше, ніж в прикладі B.

Отримані величини похибок не виглядають малими, проте потрібно врахувати те, що дана оцінка використовує мінімальні припущення — припускається лише те.



що функції розподілу є різними відносно деякої заданої міри і ліпшицевість функцій концентрації.

## ЛІТЕРАТУРА

1. Р. Є. Майборода, *Асимптотично ефективна оцінка ймовірностей, побудована по спостереженням із суміші*, Теор. ймовірност. матем. статист. **59** (1998), 121–128.
2. Р. Є. Майборода, *Непараметрична статистика неоднорідних спостережень*, Дисертація на здобуття вченого ступеня доктора фізико-математичних наук, Київ, 1994.
3. Р. Є. Майборода, *Проекційні оцінки концентрацій сумішей що змінюються*, Теор. ймовірност. матем. статист. **46** (1992), 70–76.
4. Р. Є. Майборода, *Оцінки розподілів компонентів сумішей з концентраціями, що змінюються*, Укр. мат. ж. **48** (1996), № 4, 562–566.
5. Р. Є. Майборода, *Статистичний аналіз сумішей*, Навчальний посібник, Видавничо-поліграфічний центр “Київський університет”, Київ, 2003.
6. К. Чуї, *Введення в вейвлети*, “Мир”, Москва, 2001.
7. I. Daubechies, *Ten Lectures on Wavelets*, SIAM, Philadelphia, 1996.
8. W. Härdle, *Applied Nonparametric Regression*, Cambridge University Press, Cambridge, 1990.
9. W. Härdle, G. Kerkycharian, D. Picard, A. Tsybakov, *Wavelets, Approximation, and Statistical Applications*, Springer-Verlag, New York, 1998.
10. R. E. Maiboroda, *Estimation and classification by mixtures with time-dependent concentrations*, VI International Vilnius Conference on Probability Theory and Math. Statistics. Abstracts of Communications, т. 2, 1993, стор. 48.
11. O. V. Sugakova, *Asymptotics of a kernel estimate for distribution density constructed from observations of a mixture with varying concentration*, Theor. Probab. Math. Statist. **59** (1999), 161–171.
12. B. Vidakovic, *Statistical Modeling by Wavelets*, John Wiley & Sons, New York, 1999.

КАФЕДРА ТЕОРІЙ ЙМОВІРНОСТЕЙ ТА МАТЕМАТИЧНОЇ СТАТИСТИКИ, МЕХАНІКО-МАТЕМАТИЧНИЙ  
ФАКУЛЬТЕТ, НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ ІМ. ТАРАСА ШЕВЧЕНКА, ПРОСПЕКТ ГЛУШКОВА, 6, КИЇВ  
03127, УКРАЇНА

Адреса електронної пошти: [pokhid@ukr.net](mailto:pokhid@ukr.net)

Надійшла 26/05/2004